

# 基于深层-浅层双流学习图模型的无监督少样本红外空中目标识别网络

李雨泽<sup>1</sup>, 张岩<sup>1\*</sup>, 陈宇<sup>2</sup>, 杨春玲<sup>1\*</sup>

(1. 哈尔滨工业大学 电气工程及自动化学院, 黑龙江 哈尔滨 150001;

2. 山东科技大学 电气与自动化工程学院, 山东 青岛 266590)

**摘要:** 在军事空中目标识别领域, 由于样本数量缺失, 现有人工智能算法无法完成准确识别。文章利用已有足量辅助域图像辅助少样本应用域进行跨域目标识别, 解决因标签缺失与样本稀疏导致的识别模型泛化能力不强及性能不佳问题。文章提出一种基于深层-浅层双流学习图模型(D-SLGM)的跨域目标识别算法。首先, 提出一种深层-浅层双流特征提取算法, 解决无监督少样本条件下特征表示困难的问题; 同时, 提出一种基于图模型的特征融合算法, 实现特征间高精度融合; 基于融合后的特征训练识别模型, 提升算法的泛化能力。使用自建空中目标数据集, 设计三种应用场景。实验结果表明, D-SLGM 平均识别准确率均值达到 78.2%, 优于对比方法, 在实际空中目标识别应用中具有较大潜力。

**关键词:** 目标识别; 无监督少样本学习; 特征提取; 特征融合; 图卷积网络

**中图分类号:** TP391.4 **文献标识码:** A

## An unsupervised few-shot infrared aerial object recognition network based on deep-shallow learning graph model

LI Yu-Ze<sup>1</sup>, ZHANG Yan<sup>1\*</sup>, CHEN Yu<sup>2</sup>, YANG Chun-Ling<sup>1\*</sup>

(1. School of Electrical Engineering and Automation, Harbin Institute of Technology, Harbin 150001, China;

2. College of Electrical Engineering and Automation, Shandong University of Science and Technology, Qingdao 266590, China)

**Abstract:** In the field of military aerial object recognition, due to the lack of samples, current artificial intelligence algorithms cannot perform well. This paper uses the existing sufficient auxiliary domain images to assist the application domain with few samples for cross-domain object recognition and solves the problem of weak generalization ability and poor performance of the recognition model caused by missing labels and sparse samples. A cross-domain object recognition algorithm named Deep-Shallow Learning Graph Model (D-SLGM) is proposed. Firstly, a deep-shallow two-stream feature extraction algorithm is proposed to solve the problem of feature representation under unsupervised few-shot conditions. At the same time, a feature fusion algorithm based on graph model is proposed to realize high precision fusion between features. Then, a recognition model is trained based on the fused features, the generalization ability of the algorithm is improved. The self-built aerial object dataset is adopted with three application scenarios. The experimental results show that the mean average recognition accuracy of D-SLGM reaches 78.2%, which is better than those of the comparison methods. D-SLGM has great potential in actual aerial object recognition applications.

**Key words:** object recognition, unsupervised few-shot learning, feature extraction, feature fusion, graph convolutional network

收稿日期: 2022-12-29, 修回日期: 2023-04-23

Received date: 2022-12-29, Revised date: 2023-04-23

基金项目: 国家自然科学基金(62171152, 62201327)

Foundation items: Supported by the National Natural Science Foundation of China (62171152, 62201327)

作者简介(Biography): 李雨泽(1995-), 男, 黑龙江大庆人, 博士研究生, 主要研究领域为深度学习、迁移学习、计算机视觉. E-mail: deep\_in@126.com

\* 通讯作者(Corresponding authors): E-mail: zyhit@hit.edu.cn; yangcl1@hit.edu.cn

## 引言

随着航空航天科技的快速发展,各国家新型目标的大量涌现增加了目标识别、跟踪的难度<sup>[1-2]</sup>。红外目标探测技术是目前战场上的主要探测手段之一,军事应用环境的复杂性及军事目标的保密性,使得收集覆盖全部可能环境下的红外目标图像及各种新型号目标光电特性数据非常困难。现有方法是利用光学物理成像仿真技术,产生逼真的红外目标数据,用于红外目标人工智能自动识别算法的研究。由于真实应用环境的复杂性以及各类伪装技术在实战中的广泛应用,目标仿真图像与真实图像之间存在差异,这必然导致目标识别算法在真实应用场景中性能下降。因此,有必要充分利用已有的带标签源域样本数据(仿真图像)辅助无标签少样本的新应用领域(应用场景图像)进行空中目标识别,对目标识别算法的场景适用性与泛化能力进行优化和提升。

使用特征分布适配法,通过缩小两种应用场景数据分布差异,使两种应用领域的分布更加近似,能够提高识别算法的泛化性。常见的特征分布适配法主要分为基于度量方法<sup>[3-5]</sup>和对抗算法<sup>[6-7]</sup>两种。但是在无监督少样本条件下,样本稀疏增加了特征提取算法建模的难度,导致常规的适配算法难以奏效。使用机器学习算法提取到的浅层特征是人为针对目标的光学物理性质进行设计的,在一定程度上可以对少量目标图像潜在信息进行有效挖掘与描述,因挖掘程度有限导致此方法难以取得更大的进展。深度模型通过构造多种非线性映射的方式来对大量数据中的非线性深层特征进行挖掘,进而提取到包含大量重要判定信息的嵌入特征。特征融合算法可以有效结合浅层特征与深层特征的优势<sup>[8]</sup>。文献[9]提出了一种融合浅层特征与深层特征的红外空中目标跟踪算法,该算法以多特征学习网络框架为基础,引入长宽比和均值对比度,将深层特征与浅层特征融合在一个跟踪框架中,解决了单一特征在目标跟踪中无法有效对抗面源等复杂干扰的问题。文献[10]提出一种融合底层特征与稀疏自动编码器(Sparse Autoencoder, SAE)高层视觉特征的导弹分类算法,借助SAE实现全局特征提取,融合浅层特征(颜色、纹理、轮廓),提高了当前算法的识别性能。对于无监督少样本跨域应用场景,在进行特征融合时,不仅要考虑特征包含的信息,还要利用特征之间的联系对域分布进行建

模。常用的方法包括互信息模型<sup>[11]</sup>、图正则化模型<sup>[12]</sup>、知识图模型<sup>[13]</sup>等。但是这些方法仅考虑了特征之间的线性联系,在实际应用中存在局限性。

本文建立了一种基于深层-浅层双流学习图模型(Deep-Shallow Learning Graph Model, D-SLGM)的跨域目标识别算法,结合大量源域数据(理想仿真图像)和少量目标域数据(应用场景图像),建立跨域数据分布模型,高效挖掘和提取真实目标的有效特征,构建特征非线性结构化模型,实现空间目标的准确识别。提高当前目标识别算法在少样本真实场景下的泛化能力,显著提升人工智能算法在实际应用中的识别效果。

## 1 基于深层-浅层双流学习图模型的跨域目标识别算法

### 1.1 空中目标识别模型结构设计

空中目标识别模型包括特征提取模块、特征融合模块以及目标识别模块,如图1所示。

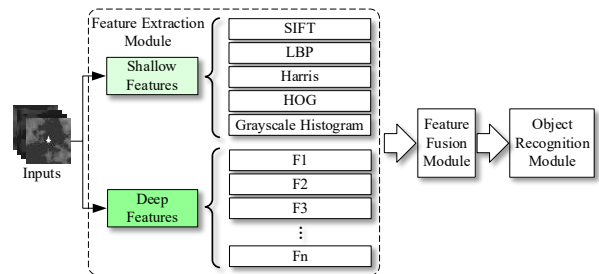


图1 空中目标识别模型结构

Fig. 1 The framework of aerial object recognition model

特征提取模块可以利用多种传统机器学习算法提取输入图像的浅层特征,同时利用深度神经网络学习深层特征。特征融合模块以图网络为基本结构,将提取到的浅层与深层特征进行高精度融合,利用图网络的多节点结构,将深层与浅层特征经变换得到32个具有抽象含义的特征,融合后的每个特征都以更抽象更概括的形式包含了目标的深层与浅层信息,实现对空中目标嵌入信息的多角度描述。在获取融合特征后,本方法通过目标识别模块,利用被式(1)所示 softmax 函数激活的全连接层进行决策识别,能够实现对四种空中目标的跨域识别。

$$f_{softmax}(x) = e^x / \sum_{i=c}^c e^{x_i} \quad , \quad (1)$$

式中, $x$ 为输入向量, $C$ 代表类别数。

## 1.2 深层-浅层双流特征提取模块

深度神经网络通过非线性映射能够挖掘图像更深、更抽象的特征,但是简单地学习样本和标签之间映射关系受到样本稀疏条件限制。传统机器学习算法可以学习到对域迁移具有鲁棒性的固有特征,减少对训练样本数量的依赖,提高跨域学习能力。通过一定规则将这些特征组合起来,能够有效地建立少样本特征空间。

### 1.2.1 深层特征提取算法

本算法通过构建深度网络模型来获取非线性特征映射,并对域不变特征进行挖掘与提取。利用生成对抗技术,挖掘最有利于描述两个域图像共性的深层特征,具体流程如图2所示,主要包括三个核心部分:深层特征提取网络 $F_f$ 、基于Wasserstein距离的分布差异度量网络 $F_w$ 和域判别网络 $F_d$ 。




图2 域不变深层特征提取模块框架

Fig. 2 Framework of domain invariant deep feature extraction module

通过深层特征提取网络,得到输入图像的深层特征。为了提高特征的类判别性,在深层特征提取框架中,添加一个辅助分类器 $F_c$ ,参数以源域图像特征 $f_s$ 及标签信息 $y_s$ 作为输入,通过如式(2)所示的交叉熵函数 $L_{cls}$ 进行训练,提高深层特征的可分性。

$$L_{cls}(f_{softmax}(f_s), y_s) = \min_{\theta_{wc}} (y_s \log(f_{softmax}(f_s))). \quad (2)$$

为了减少两个域的特征分布差异,使用Wasserstein距离<sup>[14-15]</sup>对两个域特征的边缘分布与条件分布进行联合适配,如式(3)所示。

$$\begin{aligned} L_{wd} &= (1 - \lambda_{wd})L_{wdc}(f_s, f_t) + \lambda_{wd}L_{wdm}(f_s, f_t) \\ L_{wdc}(f_s, f_t) &= \sup_{\|f_w\| \leq 1} \{E_{f_s \sim P_s}(f_w(f_s)|y_s) - E_{f_t \sim P_t}(f_w(f_t)|\tilde{y}_t)\} \\ L_{wdm}(f_s, f_t) &= \sup_{\|f_w\| \leq 1} \{E_{f_s \sim P_s}(f_w(f_s)) - E_{f_t \sim P_t}(f_w(f_t))\} \end{aligned} \quad (3)$$

其中, $f_w$ 是Wasserstein距离函数, $f_s$ 和 $f_t$ 分别表示源域

相关特征和目标域相关特征, $y_s$ 是源域真实标签, $\tilde{y}_t$ 是由辅助分类器 $F_c$ 得到的伪标签, $y_s$ 和 $\tilde{y}_t$ 的具体形式为 $1 \times 4$ 的独热码。 $\lambda_{wd}$ 是平衡边缘分布损失 $L_{wdm}$ 与条件分布损失 $L_{wdc}$ 的参数。 $\|f_w\| \leq 1$ 是Lipschitz约束,引入如式(4)所示梯度罚 $L_{grad}$ 来实现。

$$L_{grad}(x) = (\|\nabla_h f_w(x)\|_2 - 1)^2 \quad (4)$$

通过求解如式(5)所示极大极小问题拉近跨域特征分布。

$$L_{dom} = \min_{\theta_f} \max_{\theta_{wd}} (L_{wd} - \lambda_{grad} L_{grad}) \quad (5)$$

其中, $\theta_f$ 和 $\theta_{wd}$ 分别是特征提取网络 $F_f$ 和Wasserstein距离函数 $f_w$ 的参数, $\lambda_{grad}$ 是梯度惩罚因子。

为了进一步拉近不同域的数据分布,将两个域的深层特征分别输入到域判别网络 $F_d$ 中,判断输入特征来自于哪个数据域,通过对抗学习机制,进一步降低深层特征提取网络输出特征的域分布差异,直到域判别网络无法区分输入特征来自于哪个域,整个对抗学习过程结束,使用梯度反转层(Gradient Reversal Layer, GRL)提升判别网络的效率。域判别损失函数如式(6)所示。

$$\begin{aligned} L_D(f_s, f_t) &= \min_{\theta_f} \max_{\theta_{adv}} (E_{f_s \sim P_s} \log F_d(GRL(f_s)) + \\ &E_{f_t \sim P_t} \log(1 - F_d(GRL(f_t)))) \end{aligned} \quad (6)$$

其中, $\theta_f$ 和 $\theta_{adv}$ 分别是特征提取网络 $F_f$ 和域判别网络 $F_d$ 的参数,GRL( $\cdot$ )是梯度反转函数。

源域和目标域图像得到的深层特征分别为 $f_s \in \mathbb{R}^{1 \times 1024}$ , $f_t \in \mathbb{R}^{1 \times 1024}$ ,为了更清晰、直观地阐述提取到的深层特征,以图3(a)和图3(c)为样例提取深层特征,为了便于观察,将获取的深层特征以统计直方图的形式展示,如图3所示。可以看出,对于这一组样例,深层特征分布趋势大体相同,表明本文提出的深层特征提取算法能够挖掘具有一定域不变性的深层特征。

### 1.2.2 浅层特征提取算法

在少样本条件下,深层特征的学习面临过拟合问题,限制了特征提取模块的通用性,利用传统机器学习方法提取浅层特征,降低特征空间容量,可以提高学习模型的拟合能力,实现无监督少样本条件下红外空中目标样本特征的有效提取,本文研究的浅层特征包含SIFT、LBP、Harris、HOG和灰度直方图共5种特征。

#### (1) SIFT特征

尺度不变特征变换(Scale Invariant Feature Transform, SIFT)是一种局部特征描述子,通过搭建






图3 源域与目标域深层特征直方图,(a)源域图像样例,(b)源域深层特征直方图,(c)目标域图像样例,(d)目标域深层特征直方图

Fig. 3 Histograms of the deep features in source and target domains, (a) the sample in the source domain, (b) the histogram of the deep features in the source domain, (c) the sample in the target domain, (d) the histogram of the deep features in the target domain

如式(7)所示高斯差分金字塔,搜索多个尺度空间上的图像  $F(x, y, \sigma)$  来检测对尺度不变的特征关键点。

$$D(x, y, \sigma) = (G(x, y, k\sigma) - G(x, y, \sigma)) \otimes I(x, y) \\ = F(x, y, k\sigma) - F(x, y, \sigma) \quad (7)$$

式中,  $G(x, y, \sigma) = e^{-(x^2 + y^2)/2\sigma^2} / 2\pi\sigma^2$  为高斯函数,  $I(x, y)$  为原始图像,  $\otimes$  代表卷积操作,  $\sigma$  是标准差, 通过调整  $\sigma$  值获取多尺度图像。计算差分金字塔的极值, 对关键点进行定位, 基于关键点局部梯度方向为关键点赋方向。在描述关键点时, 以关键点为中心, 先旋转到特征点主方向, 保障了特征的旋转不变性。围绕关键点构建  $4 \times 4$  个子区域, 每个子区域构建方向梯度, 每隔  $45^\circ$  取一个划分, 共划分 8 部分, 最终的特征向量为 128 维。

使用词袋算法 (Bag of Feature, BoF) 进一步挖掘 SIFT 关键点之间存在的共性与特性。对图像关键点进行聚类, 聚类中心代表一组关键点的共性, 根据聚类中心得到图像的关键点直方图。

## (2) LBP 特征

局部二值模式 (Local Binary Pattern, LBP) 特征具有灰度不变性和旋转不变性, 通过式(8)计算图

像 LBP 特征图。

$$LBP(x, y) = \sum_{n=0}^{n-1} 2^n I(i_n > i) \quad (8)$$

式中,  $i$  是所求像素点的像素值,  $i_n$  是像素周边八个相邻像素的像素值,  $I(\cdot)$  表示指示函数, 当  $i_n > i$  时取 1, 当  $i_n < i$  时取 0。八个相邻像素依次作为起点, 得到八个 LBP 值, 取其中最小值作为当前像素的 LBP 值。

## (3) Harris 特征

Harris 特征是一种角点检测特征, 具有旋转不变性, 利用式(9)提取目标角点特征。

$$M = w(x, y) \otimes \begin{bmatrix} I_x^2 & I_x I_y \\ I_x I_y & I_y^2 \end{bmatrix} \quad (9)$$

式中,  $\otimes$  代表卷积操作,  $I_x$  和  $I_y$  分别为当前像素点的水平方向与垂直方向的导数,  $w(x, y)$  表示窗口函数, 形式通常为常数或者高斯函数。利用式(10)计算目标角点响应值。

$$R = \text{Det}(M) - k \times \text{Trace}^2(M) \quad (10)$$

式中,  $\text{Det}(M)$  和  $\text{Trace}(M)$  分别用于求取  $M$  的行列式与迹, 通常  $k \in [0.04, 0.06]$ 。排除  $R$  值小于设定阈值的像素, 并采用局部非极大值抑制算法确定最终角点。

## (4) HOG 特征

方向梯度直方图 (Histogram of Oriented Gradient, HOG) 特征具有几何不变性, 通过统计局部区域的梯度方向直方图来构成特征, 首先使用 Sobel 算子计算每个像素的水平梯度  $g_x$  和垂直梯度  $g_y$ , 通过式(11)得到该像素的梯度幅值  $g$  与方向  $\theta(x, y)$ 。

$$g = \sqrt{g_x^2 + g_y^2} \\ \theta(x, y) = \arctan(g_y/g_x) \quad (11)$$

将图像划分为元胞, 将梯度方向平均分成 9 个方向, 统计元胞内像素梯度直方图。若干元胞组成一个特征块, 特征块内将所有元胞的特征串联起来, 块内归一化梯度直方图, 得到这个块的 HOG 特征描述, 将图像中所有块的 HOG 特征串联起来得到这张图像的 HOG 特征。

## (5) 灰度直方图特征

灰度直方图可以用来描述不同灰度值的像素在图像中所占比例。该特征具有尺度、平移、旋转不变性, 其具体表达式如式(12)所示。

$$H_p = [h_1, h_2, \dots, h_k, \dots, h_L] \quad (12)$$

式中,  $H_p$  表示灰度直方图特征,  $h_k = n_k/N$ ,  $n_k$  表示灰度值为  $k$  的像素在图像中所占的个数,  $N$  表示像素总数。

本文提取到的SIFT、HOG和灰度直方图特征为 $1 \times 16$ 的特征向量,LBP与Harris特征为二维特征矩阵,其维度与输入图像维度相同。进一步地,本文采用神经网络将LBP与Harris特征降维至 $1 \times 16$ 的特征向量,使其维度与其他浅层特征维度一致,以便更好地实现后续特征融合。为了更直观地展示所提取到的浅层特征,本节以一个样本图像作为样例,将提取的5个浅层特征以柱状图的形式在图4中显示。从图4中可见,这五种特征之间存在较强的差异性,从不同的角度对图像的判别信息进行描述。

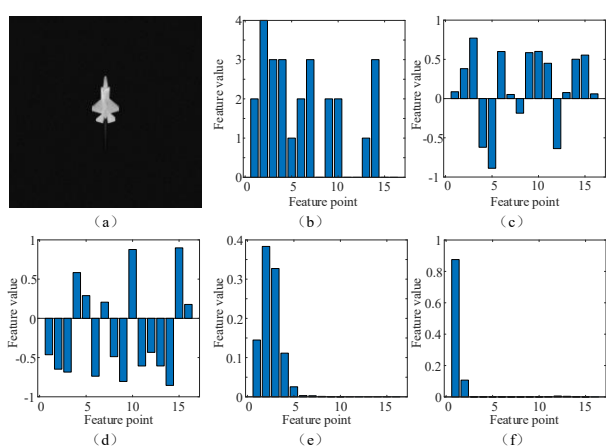


图4 浅层特征柱状图,(a)样例,(b)SIFT,(c)LBP,(d)Harris,(e)HOG,(f)灰度直方图

Fig. 4 Bar charts of shallow features, (a) the sample, (b) SIFT, (c) LBP, (d) Harris, (e) HOG, (f) grayscale histogram

### 1.3 浅层特征与深层特征融合算法

深层与浅层特征从不同角度描述目标,为保障信息的完整性,融合两种特征有利于后续的任务。本文提出一种基于图网络的特征融合算法,利用特征本身信息及其之间的关系,融合深层特征的深层语义表征与浅层特征在尺度、旋转等方面的不变性表征,获得更加鲁棒的嵌入表示。特征融合网络结构图如图5所示。

本文使用图卷积网络(Graph Convolutional Network, GCN)挖掘特征之间的潜在关系。深度GCN的拓扑是一个标准的前向神经无向图网络,GCN的输出如式(13)所示。

$$Z^{l+1} = G(Z^l, A) = \sigma(AZ^l W) \quad (13)$$

其中, $\sigma$ 表示非线性激活函数, $Z^l$ 为第 $l$ 层节点的输入特征, $A$ 表示节点的相邻矩阵,本文利用余弦距离相似性来表示每个节点对的关系, $W$ 为学习权重。为了保证计算的稳定性,将GCN进行标准化变换,




图5 基于GCN的特征融合模块框架

Fig. 5 Framework of GCN-based feature fusion module

如式(14)所示。

$$Z^{l+1} = \sigma(D^{-\frac{1}{2}} \bar{A} D^{-\frac{1}{2}} Z^l W) \quad (14)$$

其中, $\bar{A} = A + I$ , $I$ 是单位阵, $D_{ii} = \sum_j \bar{A}_{ij}$ 。 $\bar{A}$ 的特征值被限制在 $[0, 1]$ 的范围内,因此计算具有稳定性。

使用交叉熵损失函数 $L_g$ 来评估分类性能,如式(15)所示。使用小批量随机梯度下降算法更新GCN参数,优化图关系学习过程。

$$L_g(f_{softmax}(z), y) = y \log(f_{softmax}(z)) \quad (15)$$

在每次迭代训练过程中,首先通过式(2)优化 $\theta_f$ ,以获取具有类别信息的深层特征,之后通过式(5)依次优化 $\theta_{wd}$ 和 $\theta_f$ ,最后通过式(6)进一步优化 $\theta_{adv}$ 和 $\theta_f$ ,以获取域不变特征。将获得的深层特征与浅层特征串联起来,输入到特征融合网络中,通过式(15)以最终的性能为判别标准优化GCN。

融合后的特征为 $z \in R^{1 \times 2208}$ ,该特征是图卷积网络32个节点的输出(每个节点输出69维特征向量)融合得到的,为了更直观地阐述,以图6(a)和图6(c)为样例提取融合后的特征,为了便于观察,将融合后的特征以统计直方图的形式展示,如图6所示。对于这一组样例,融合后的特征分布趋势大体一致,相较于所提取到的深层特征,具有更强的域不变性。

## 2 实验验证与结果分析

### 2.1 实验数据源

考虑到军事应用环境的复杂性及军事目标的保密性,收集覆盖全部可能环境下的红外空中目标图像及各种新型号目标光电特性数据非常困难。基于已有的典型红外目标仿真成像系统,设定空中运动位姿状态、观测背景、探测器响应模型等条件,构建不同的典型空中目标探测场景,用于后续验证本文方法在训练集与测试集不同源的情况下的有效性。上述仿真成像系统采用的仿真计算机的CPU为Intel i7-9700 3.6 GHz, GPU为Nvidia




图6 源域与目标域融合后特征直方图,(a)源域图像样例,(b)源域融合特征直方图,(c)目标域图像样例,(d)目标域融合特征直方图

Fig. 6 Histograms of the fused features in source and target domains, (a)the sample in source domain, (b)the histogram of the fused features in source domain, (c)the sample in target domain, (d)the histogram of the fused features in target domain

RTX2060,内存容量为 32 GB。软件采用 C/C++ 语言进行开发,对应的集成开发环境为 Qt,数据库系统采用关系型数据库管理系统 MySQL。本文所提算法 D-SLGM 采用的开发语言为 Python,使用的深度学习开发框架为 TensorFlow。

本文实验数据源包含四个子集:1)理想红外仿真图像子集(S),包含四类目标(A,B,C,D),模拟目标在不同观测视角下的状态,主要体现空中目标的几何形状与辐射强度,以该子集作为源域;2)模糊目标红外仿真图像子集(T1),增强调制函数对成像系统的影响,模拟光学成像链路影响较大的情况,仿真生成的图像较为模糊;3)小目标红外仿真图像子集(T2),模拟观测距离较远情况下的空中目标在不同观测视角下的状态,增加云层背景,并且使用系统调制函数对系统的空间调制效应加以模拟;4)云层目标红外仿真图像子集(T3),在 T2 基础上增大量化系数,使得云层更加明显。典型空中目标部分图像样本示例如图 7 所示。

## 2.2 空中目标识别算法性能验证实验结果分析

选择五种典型算法作为对比实验:卷积神经网络(CNN)、深度适配网络(DAN)<sup>[5]</sup>、联合分布适配网络(JAN)<sup>[16]</sup>、特定风险外推法(VREx)<sup>[17]</sup>、对比邻域




图7 典型空中目标图像数据集部分样本示例

Fig. 7 Samples of typical aerial object images

空间算法(CoVi)<sup>[18]</sup>。CNN 直接将利用源域数据训练好的识别模型用于执行目标域的识别任务,作为基线算法验证其他跨域识别算法的有效性。

设计了三个跨域识别任务,分别是: S→T1, S→T2, S→T3。实验中,对所有输入图像进行统一预处理,缩放至 227×227 尺寸,并减去像素均值。本文使用平均识别准确率(Average Accuracy, AAc)作为算法单个跨域识别任务的评价指标,如式(16)所示。

$$AAc = N_{f_i=y} / N \quad (16)$$

其中,  $N$  为样本总数,  $N_{f_i=y}$  为该跨域识别任务下识别结果正确的样本数。本文使用平均识别准确率均值(mean Average Accuracy, mAac)衡量算法在多个跨域识别任务的整体性能,如式(17)所示。

$$mAac = \frac{1}{n} \left( \sum_{i=1}^n AAc_i \right) \quad (17)$$

其中,  $n$  为跨域识别任务总数。

表 1 给出了基于 D-SLGM 的空中目标识别算法和对比算法在本文仿真数据集上的实验结果。可以看出,本文提出的算法在三组实验中均明显高于基线算法,对比最新的两种方法 VREx 和 CoVi,平均准确率均值分别高 4.9% 和 2.0%。

## 2.3 D-SLGM 识别模型各模块性能验证

本节使用消融实验方法对本算法深层特征提取模块、浅层特征提取模块与基于图网络的特征融合模块的有效性进行分析。构建三种对比网络模型,即:SLGM 模型,移除深层特征提取模块;DLGM 模型,移除浅层特征提取模块,保留域适配算法与



表1 空中目标数据集上各算法识别准确率(%)

Table 1 Accuracies of different algorithms on aerial objects datasets (%)

方法	跨域识别任务			mAAc
	S→T1	S→T2	S→T3	
CNN	62.8	56.9	37.2	52.3
DAN	96.7	74.1	39.1	70.0
JAN	97.9	75.8	40.1	71.3
VREx	97.7	77.4	44.8	73.3
CoVi	97.2	87.3	44.1	76.2
D-SLGM	99.3	88.9	46.5	78.2

图卷积网络;D-SLM模型,移除基于图网络的融合模块,将深层与浅层特征串联输出。通过比较三种对比网络模型与完整D-SLGM模型的识别性能,验证各模块的有效性,结果如表2所示。


表2 D-SLGM方法的消融实验结果(%)

Table 2 Results of ablation experiments on D-SLGM (%)

方法	跨域识别任务			mAAc
	S→T1	S→T2	S→T3	
SLGM	58.0	66.8	30.7	51.8
DLGM	98.1	82.6	41.3	74.0
D-SLM	98.9	85.6	40.9	75.1
D-SLGM	99.3	88.9	46.5	78.2

本节还对D-SLGM模型的参数敏感性进行了分析,重点研究了联合分布适配损失函数 $L_{wd}$ 中的超参数 $\lambda_{wd}$ ,设置 $\lambda_{wd}$ 的取值为 $\{0.0, 0.1, 0.3, 0.5, 0.7, 0.9, 1.0\}$ ,记录三个跨域任务在每个取值下的识别准确率,其结果如图8所示。

可以看出,初始阶段,准确率随着 $\lambda_{wd}$ 的增大逐渐增大,当 $\lambda_{wd}>0.5$ 时,准确率随着 $\lambda_{wd}$ 的增大逐渐降

图8 超参数 $\lambda_{wd}$ 敏感性分析的实验结果Fig. 8 Experimental results on the sensitivity of hyperparameter  $\lambda_{wd}$ 

低。通过实验选择 $\lambda_{wd}=0.5$ ,此时准确率达到峰值。D-SLGM模型在较大的参数变化范围内都能够取得较高的准确率,可见D-SLGM模型对参数变化具有一定的鲁棒性。

## 2.4 可视化分析

本节利用t-SNE可视化方法,对D-SLGM所提取并融合后的特征进行直观表示。实验以S→T1任务为实验对象,对仅使用CNN基线算法提取到的特

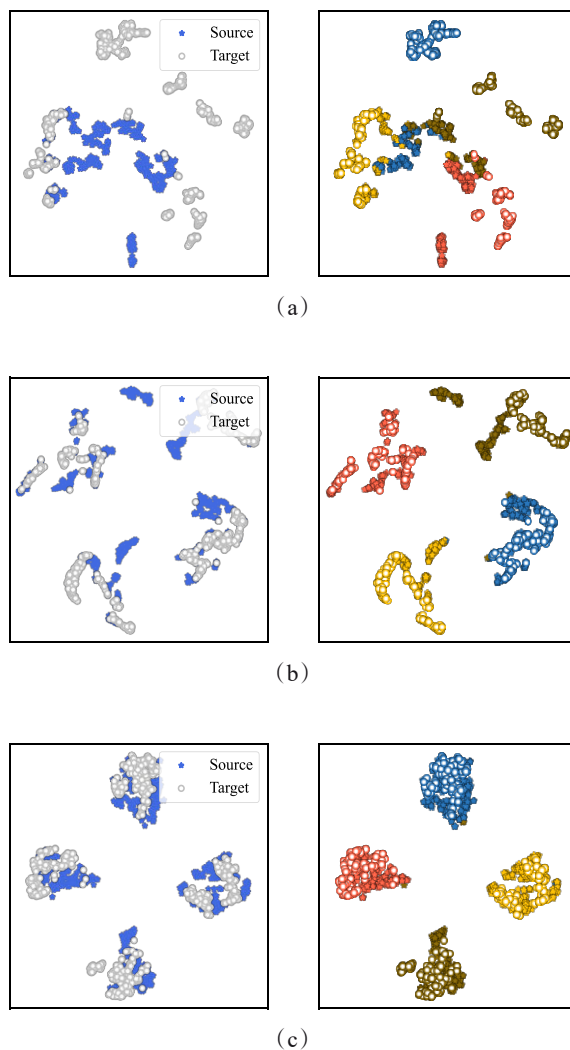


图9 D-SLGM模型特征可视化结果,(a) CNN基线算法提取特征分布可视化结果,(b)D-SLGM模型提取到的域不变深层特征分布可视化结果,(c)D-SLGM模型最终特征分布可视化结果

Fig. 9 Results of feature visualization for D-SLGM algorithm, (a) visualization of the deep features extracted by baseline CNN, (b) visualization of the domain invariant deep features extracted by D-SLGM, (c) visualization of the final features extracted by D-SLGM

征分布,以及本文方法提取到的深层特征和经过 GCN 融合后的特征分布进行降维可视化处理,其结果如图 9 所示。其中,左侧子图为源域和目标域分布情况,同种颜色和形状来源于相同的数据域,右侧子图为类别分布情况,同种颜色为同一类别。

图 9(a)中可以发现,未进行域适配、来自不同数据域的同类别目标特征分布距离较远,很容易被错误分类。图 9(b)中可以发现,进行域适配后,不同域同类别深层特征分布的两个簇之间的分布距离缩短,但是不同数据域的同类别样本特征分布没有很好地混合在一起。图 9(c)中可以看出,相较于单纯的深层特征,本文算法得到的不同数据域同类别样本特征分布相似性更高。

### 3 结论

本文研究建立了一种新的无监督红外空中目标识别模型,提出一种基于深层-浅层双流学习图模型(Deep-Shallow Learning Graph Model, D-SLGM)的无监督少样本目标识别算法,首先研究了样本稀疏条件下图像特征的特征与学习方法,设计了基于深层-浅层双流特征提取方法,使用人为定义的浅层特征辅助深层特征,极大地降低了识别任务对样本数量的需求。在此基础上,利用深度图卷积网络挖掘特征之间的关系信息,实现深层特征与浅层特征之间的高精度融合,能够提高识别系统在实际应用场景的识别精度。最后,构建了多场景空中目标图像数据集,验证本文算法在不同场景下的性能。实验结果表明,本文所提出的空中目标识别算法在多场景空中目标仿真数据集上的平均识别准确率均值达到 78.2%,证明了 D-SLGM 模型在跨域空中目标识别任务上的有效性。

### References

- [1] LI Kai-Yong, HE You-Jin, ZHANG Peng, *et al.* A method for ground target recognition through IR imaging [J]. *Electronics Optics & Control* (李凯永,何友金,张鹏,等.地面红外目标图像识别方法研究. *电光与控制*), 2009, **16**(03): 71-74.
- [2] Sun S G, Park H W. Automatic target recognition using boundary partitioning and invariant features in forward-looking infrared images [J]. *Optical Engineering*, 2003, **42**(2): 524-533.
- [3] Pan S J, Tsang I W, Kwok J T, *et al.* Domain adaptation via transfer component analysis [J]. *IEEE Transactions on Neural Networks*, 2010, **22**(2): 199-210.
- [4] Tzeng E, Hoffman J, Zhang N, *et al.* Deep domain confusion: maximizing for domain invariance [J]. *arXiv preprint arXiv*, 1412.3474, 2014.
- [5] Long M, Cao Y, Cao Z, *et al.* Learning transferable features with deep adaptation networks: proceedings of the 32nd International Conference on Machine Learning, 2015 [C]. Lille: IMLS, 2015: 97-105.
- [6] Ganin Y, Ustinova E, Ajakan H, *et al.* Domain adversarial training of neural networks [J]. *The Journal of Machine Learning Research*, 2016, **17**(1): 1-35.
- [7] Zhou Q, Zhou W, Wang S, *et al.* Multiple adversarial networks for unsupervised domain adaptation [J]. *Knowledge-Based Systems*, 2021, **212**: 106606.
- [8] Liu Z, Wang S, Zheng L, *et al.* Robust imagegraph: rank-level feature fusion for image search [J]. *IEEE Transactions on Image Processing*, 2017, **26**(7): 3128-3141.
- [9] HU Yang-Guang, XIAO Ming-Qing, ZHANG Kai, *et al.* Infrared aerial target tracking based on fusion of traditional feature and deep feature [J]. *Systems Engineering and Electronics* (胡阳光,肖明清,张凯,等.传统特征和深度特征融合的红外空中目标跟踪. *系统工程与电子技术*), 2019, **41**(12): 2675-2683.
- [10] CHEN Yu, WEN Xin-Ling, LIU Zhao-Yu, *et al.* Research of multi-missile classification algorithm based on sparse auto-encoder visual feature fusion [J]. *Infrared and Laser Engineering* (陈宇,温欣玲,刘兆瑜,等.稀疏自动编码器视觉特征融合的多弹分类算法研究. *红外与激光工程*), 2018, **47**(08): 386-393.
- [11] Yang W, Greg M. A discriminative latent model of object classes and attributes: 11th European Conference on Computer Vision, 2010 [C]. Heraklion: Springer, 2010: 155-168.
- [12] GONG Ping, CHENG Yu-Hu, WANG Xue-Song. Zero-shot classification based on attribute correlation graph regularized feature selection [J]. *Journal of China University of Mining & Technology* (巩萍,程玉虎,王雪松.基于属性关系图正则化特征选择的零样本分类. *中国矿业大学学报*), 2015, **44**(6): 1097-1104.
- [13] Wang X, Ye Y, Gupta A. Zero-shot recognition via semantic embeddings and knowledge graphs: proceedings of the IEEE conference on computer vision and pattern recognition, 2018 [C]. Salt Lake City: IEEE, 2018: 6857-6866.
- [14] Gulrajani I, Ahmed F, Arjovsky M, *et al.* Improved training of wasserstein GANs: advances in neural information processing systems, 2017 [C]. Long Beach: Neural information processing systems foundation, 2017: 5768-5778.
- [15] Shen J, Qu Y, Zhang W, *et al.* Wasserstein distance guided representation learning for domain adaptation: proceedings of the AAAI Conference on Artificial Intelligence, 2018 [C]. New Orleans: AAAI, 2018: 4058-4065.
- [16] Long M, Wang J, Jordan M I. Deep transfer learning with joint adaptation networks: proceedings of the International Conference on Machine Learning, 2017 [C]. Sydney: IMLS, 2017: 3470-3479.
- [17] Krueger D, Caballero E, Jacobsen J H, *et al.* Out-of-distribution generalization via risk extrapolation [J]. *arXiv preprint arXiv*, 2003.00688, 2021.
- [18] Na J, Han D, Chang H J, *et al.* Contrastive vicinal space for unsupervised domain adaptation: 17th European Conference on Computer Vision, 2022 [C]. Tel Aviv: Springer Science and Business Media Deutschland GmbH, 2022: 92-110.